基于 PSO-ELM 的机器人精度补偿方法研究 *

冯禹铭，董秀成，金　滔

(西华大学 信号与信息处理重点实验室，成都 610039)

摘　要：为了提高机器人的定位精度，对传统的基于神经网络的机器人精度补偿方法进行改进。采用两种基于粒子群优化的极限学习机（PSO-ELM）模型的精度补偿方法对机器人关节坐标及直角坐标进行补偿。分别对两种方法进行仿真实例分析和比较，并与遗传算法优化的极限学习机（GA-ELM）模型进行对比。仿真结果表明，对直角坐标进行补偿的 PSO-ELM 机器人精度补偿法优于其他补偿方法，且具有较高的预测精度。

关键词：机器人；精度补偿；极限学习机；PSO-ELM

中图分类号：TP242.2　　doi: 10.3969/j.issn.1001-3695.2018.03.0210

Research on methods of robot accuracy compensation based on PSO-ELM

Feng Yuming, Dong Xiucheng, Jin Tao

(*Signal &Information Processing Laboratory*, *Xihua University*, *Chengdu* 610039, *China*)

Abstract: In order to improve the robot position accuracy, the traditional method of robot accuracy compensation based on neural network is improved. Two methods of robot accuracy compensation based on extreme learning machine with particle swarm optimization (PSO-ELM) are used to compensate for joint coordinate of robot and cartesian coordinate of robot. The two methods are analyzed and compared by simulation examples, and compared with the extreme learning machine with genetic algorithm optimization (GA-ELM) . The simulation results show that the method of robot accuracy compensation based on PSO-ELM compensates for cartesian coordinate is superior to other compensation methods, and has high prediction accuracy.

Key words: robot; accuracy compensation; extreme learning machine; PSO-ELM

0　引言

近年来，机器人已被广泛用于要求高精度的工作，如离线编程，机器人辅助手术等。由于加工公差、装配公差、机器人的结构变形等多种原因，使机器人的实际运动学模型参数和它的名义参数值不同。这种误差明显降低了机器人的定位精度。因此，在机器人使用之前，机器人应进行必要的校准过程来提高定位精度。

机器人运动学模型的误差源可以分为两类：几何参数误差，如连杆长度和连杆扭曲误差等；非几何误差，如齿轮侧隙、连杆和关节的柔性等[1,2]。一些研究专注于模型的建立和几何参数误差的辨识而忽略了非几何误差[3~6]。这些研究假设非几何误差对机器人位置误差影响非常小。但这些非几何误差仍然会影响机器人的定位精度[7]。于是，有些学者提出了基于神经网络的实时误差补偿[8~10]。这种方法大概可以分为两类，一种以关节角和对应关节角误差分别作为 BP 神经网络的输人和输出，得到在任意关节角时的误差值，通过修正关节角来实现位置误差的补偿[11];另一种以关节角和对应的实际坐标位置偏离作为 BP 神经网络的输入和输出，再通过对关节角进行补偿来提高机器人的定位精度[12]。传统的 BP 神经网络虽然在机器人的实时补偿中有一定效果，但是由于自身模型的限制，容易陷入局部最优解，且训练时间较长，影响实时补偿的效率。ELM[13]是 Huang 等人针对传统神经网络算法的固有缺点提出的一种单隐含层前馈神经网络的学习算法，与传统的 BP 算法不同，ELM 随机产生输入层和隐层之间的连接权值以及隐含层神经元的阈值。由于其极快的学习速度和泛化性能好等优点。它在模式识别，计算机视觉，数据挖掘，信号处理，和控制系统中得到了广泛的应用。

本文将粒子群（PSO）和极限学习机（ELM）相结合的 PSO-ELM 模型对上述的两种基于神经网络的机器人精度补偿方法[11~12]进行改进，同时引入遗传算法（GA）和极限学习机（ELM）相结合的 GA-ELM[14]模型进行对比，最后，再对改进后的这两种方法的效果进行对比分析。

收稿日期：2018-03-28；**修回日期：**2018-05-17　　**基金项目：**四川省高校科研创新团队—机器视觉与智能控制（18TD0024）；四威高科—西华大学产学研联合实验室（2016-YF04-00044-JH）；国家教育部“春晖计划”科研项目（Z2017076）

作者简介：冯禹铭（1993-），男，四川成都人，硕士研究生，主要研究方向为机器人技术（851648009@qq.com）；董秀成（1963-），男，四川成都人，教授，硕导，硕士，主要研究方向为机器视觉、机器人技术；金滔（1992-），男，四川合江人，硕士研究生，主要研究方向为机器人技术.

1　极限学习机模型

ELM 的网络训练采用单层的隐层前馈结构[15]。假设存在 n 个输入层神经元和 o 个输出输出层神经元，分别表示 n 个输入变量和 o 个输出变量，设置隐含层神经元数为 h 。假设有 N 个不同的样本 (x_i,t_i)，$1\le i\le N$，$x_i=[x_{i1},x_{i2},...,x_{in}]^T\in R^n,t_i=[t_{i1},t_{i2},...,t_{io}]^T\in R^o$；ELM 的训练模型如图 1 所示：

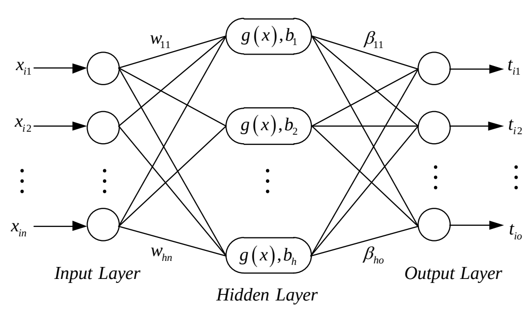


图 1　ELM 的训练模型

ELM 的网路模型可以表达如下：

$$\sum_{i=1}^{h}\beta_i g(w_i.x_i+b_i)=r_j,\ j=1,2,...o \qquad (1)$$

其中：$w_i=[w_{i1},w_{i2},...,w_{in}]$ 是所有输入层神经元连接第 i 个隐层神经元之间的输入权值向量，b_i 是第 i 层隐层神经元的阈值。$\beta_i=[\beta_{i1},\beta_{i2},...,\beta_{ih}]$ 是第 i 个隐层神经元连接所有输出神经元的权值向量，$\gamma_j=[\gamma_{j1},\gamma_{j2},...,\gamma_{jo}]^T$ 是 ELM 的输出值。代价函数可以表示如下：

$$c(WB,\beta)=\sum_{j=1}^{N}|r_j-t_j| \qquad (2)$$

$WB=[w_i,b_i,i=1,2,...,h]$ 训练 ELM 的目标是找到最优的 WB 和 β 使得输出值和实际值的误差最小，所以，$\min C(WB,\beta)$ 可以被写作以下的形式：

$$\min C(WB,\beta)=\min_{wi,bi,\beta}|H(w_1,...,w_h;b_1,...,b_h;x_1,...,x_n)\beta-T| \qquad (3)$$

其中：H 是样本中隐层神经元的输出矩阵，T 是样本集的目标矩阵。

$$H(w_1,w_2,\cdots,w_h;b_1,b_2,\cdots,b_h;x_1,x_2,\cdots,x_N)=\begin{bmatrix} g(w_1x_1+b_1) & \cdots & g(w_hx_1+b_h)\\ \vdots & \cdots & \vdots \\ g(w_1x_N+b_1) & \cdots & g(w_hx_N+b_h)\end{bmatrix}_{N\times h} \qquad (4)$$

等式（3）等价于求 $H\beta=T$ 的最小二乘解，即求使得代价函数最小的最优权值$\hat{\beta}$，

$$\hat{\beta}=H^{+}T \qquad (5)$$

H^{+} 是 H 的 Moore-Penrose 广义逆矩阵。

2　基于 PSO 优化的 ELM 算法

粒子群优化算法由 Eberhart 和 Kennedy 基于人群的社会行为理论提出的[16]，该算法作为一种新兴的进化算法，起源于鸟类觅食的模拟，对于 N 个参数的最优辨识具有原理简单，易于实现的特点。

根据 ELM 的基本原理可以看出 ELM 的输入层权值矩阵 w 和隐含层阈值矩阵 b 是随机生成的，因此，在 ELM 模型固定的情况下，会造成 ELM 的预测误差很大，PSO 具有良好的全局寻优能力，PSO 可以为 ELM 模型找到最优的初始的 w 和 b，从而得到最优 ELM 模型。PSO-ELM 算法的主要步骤如下：

a）实验数据的预处理。将实验数据分为训练集和测试集，并进行归一化。

b）初始化。初始化粒子群参数，ELM 模型的网络结构参数。第 i 个粒子位置 $X_i=[w_{11},\cdots,w_{h1},\cdots,w_{1n},\cdots,w_{hn},b_1,\cdots,b_h]$，其中，$w_{ji}$，$j=1,\cdots,h$，$i=1,\cdots,n$，是第 i 个输入层神经元与第 j 个隐层神经元之间的连接权值，b_j 是第 j 层隐层神经元的阈值。

c）寻找初始极值。将粒子位置 X_i 和训练样本数据代入 ELM 模型，得到 ELM 的输出预测值，从而计算出粒子的适应度值。并寻找个体极值和群体极值，同时记忆个体极值和群体极值的位置及适应度值。粒子的适应度函数取为

$$f=\frac{1}{\sqrt{\frac{1}{N}\sum_{i=1}^{N}(\bar{Y}_i-Y_i)^2}} \qquad (6)$$

其中：$\bar{Y}_i$ 为训练样本的 ELM 输出预测值，Y 为训练样本的真值，N 为训练样本的个数。

d）惯性权重的选择。在经过一些迭代后，每个粒子的位置逐渐收敛到最佳位置。为了提高前期迭代的全局搜索能力后期迭代的局部优化能力，惯性权重ω随迭代次数 j 的增加而线性减小。

$$\omega=\omega_{\max}-(\omega_{\max}-\omega_{\min})\frac{j-1}{J-1} \qquad (7)$$

其中：$\omega_{\max}$ 和 $\omega_{\min}$ 是最惯性权重的最大值和最小值，J 是最大的迭代次数

e）迭代寻优。每次迭代的过程中，粒子通过个体极值和群体极值更新自身的速度和位置，最终得到最优个体的适应度值和对应的粒子位置。

f）完成 PSO-ELM 模型。最优个体对应的粒子位置即是 ELM 的最优网络初始权值和阈值，将其代入 ELM 模型，用测试集样本对 ELM 进行测试及效果评价。

PSO-ELM 的算法流程如图 2 所示。

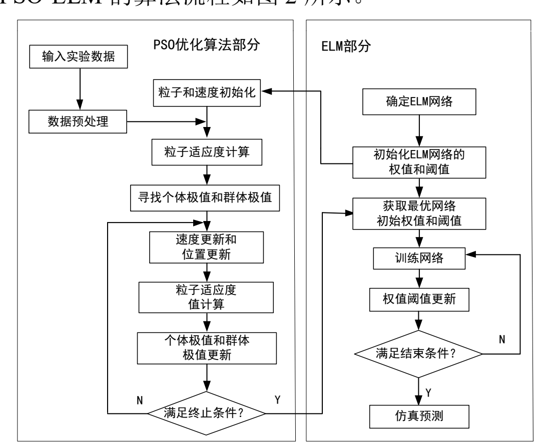


图 2　PSO 优化 ELM 的算法流程

3　基于 PSO-ELM 的机器人精度补偿仿真实例

3.1　ABB 机器人的几何模型

本文采用 DH 法建立 ABB 机器人的运动学模型，ABB 机器人的结构图如图 3 所示。

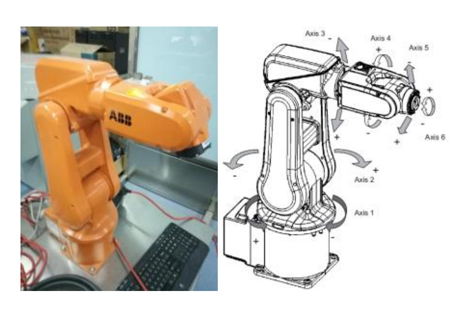


图 3　ABB 机器人的结构图

在建立了坐标系 0 后，从坐标系 1 开始，通过使用坐标系 $i-1$ 来定义坐标系 i，两个相邻的连杆的 DH 坐标系的齐次变换矩阵如下：

$$T_i^{i-1} = Rot(z,\theta_i)Trans(0,0,d_i)Trans(a_i,0,0)Rot(x,\alpha_i) \quad (8)$$

可以得到：

$$T_i^{i-1} = \begin{bmatrix} \cos\theta_i & -\sin\theta_i\cos\alpha_i & \sin\theta_i\sin\alpha_i & a_i\cos\theta_i \\ \sin\theta_i & \cos\theta_i\cos\alpha_i & -\cos\theta_i\sin\alpha_i & a_i\sin\theta_i \\ 0 & \sin\alpha_i & \cos\alpha_i & d_i \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

其中：$a_i,\alpha_i,d_i,\theta_i$ 分别表示第 i 个轴的连杆长度，连杆扭曲，连杆偏置和关节角度。给定 ABB 机器人的标准 D-H 参数值如表 1 所示，其中，a_i、d_i 的单位为 mm，α_i、θ_i 的单位为 rad。

表 1　标准 D-H 参数值

i	a_i	α_i	d_i	θ_i	θ_i的范围
1	0	$-pi/2$	187	θ_1	$-165^\circ \sim 165^\circ$
2	230	0	0	θ_2	$-110^\circ \sim 110^\circ$
3	107	$-pi/2$	0	θ_3	$-90^\circ \sim 70^\circ$
4	0	$pi/2$	168	θ_4	$-160^\circ \sim 160^\circ$
5	0	$-pi/2$	0	θ_5	$-120^\circ \sim 120^\circ$
6	0	0	0	θ_6	$-400^\circ \sim 400^\circ$

用 s_i 表示 $\sin\theta_i$，c_i 表示 $\cos\theta_i$，由表 1 可得，各连杆的变换矩阵如下：

$$T_1^0 = \begin{bmatrix} c_1 & 0 & -s_1 & 0 \\ s_1 & 0 & c_1 & 0 \\ 0 & -1 & 0 & 187 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad T_2^1 = \begin{bmatrix} c_2 & -s_2 & 0 & 230c_2 \\ s_2 & c_2 & 0 & 230s_2 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix},$$

$$T_3^2 = \begin{bmatrix} c_3 & 0 & -s_3 & 107c_3 \\ s_3 & 0 & c_3 & 107s_3 \\ 0 & -1 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad T_4^3 = \begin{bmatrix} c_4 & 0 & s_4 & 0 \\ s_4 & 0 & -c_4 & 0 \\ 0 & -1 & 0 & 168 \\ 0 & 0 & 0 & 1 \end{bmatrix},$$

$$T_5^4 = \begin{bmatrix} c_5 & 0 & -s_5 & 0 \\ s_5 & 0 & c_5 & 0 \\ 0 & -1 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad T_6^5 = \begin{bmatrix} c_6 & -s_6 & 0 & 0 \\ s_6 & c_6 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

将各个连杆的变换矩阵相乘，就可以得到机械手末端相对于基坐标系的变换矩阵：

$$T_E = T_6^0 = T_1^0T_2^1T_3^2T_4^3T_5^4T_6^5 = \begin{bmatrix} n_x & o_x & a_x & p_x \\ n_y & o_y & a_y & p_y \\ n_z & o_z & a_z & p_z \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (9)$$

机器人的末端位置向量可以表示为 $X = [P_x, P_y, P_z]^T$，机器人的末端位置误差可以表示为 $\Delta X = \sqrt{\Delta x^2 + \Delta y^2 + \Delta z^2}$，若用上角标字母 N 表示理论值，字母 R 表示实际值。则位置总误差可以表示为 $\Delta X = \sqrt{(p_x^R - p_x^N)^2 + (p_y^R - p_y^N)^2 + (p_z^R - p_z^N)^2}$。

3.2　实验数据的获取

假设表 1 中 ABB 机器人相应的标准 D-H 参数值的几何误差如表 2 所示。其中，Δa_i、Δd_i 的单位为 mm，$\Delta\alpha_i$、$\Delta\theta_i$ 的单位为 rad。即 ABB 机器人的实际 D-H 参数 $\alpha_i^R = \alpha_i + \Delta\alpha_i$，$a_i^R = a_i + \Delta a_i$，$d_i^R = d_i + \Delta d_i$，$\theta_i^R = \theta_i + \Delta\theta_i$。

表 2　标准 D-H 参数值的几何误差

i	Δa_i	$\Delta\alpha_i$	Δd_i	$\Delta\theta_i$
1	0.1	0.0015	0.15	-0.0016
2	0.12	0.0018	0.08	0.0018
3	0.15	0.0016	0.10	0.0015
4	0.08	0.0015	0.14	0.0013
5	0.09	0.0014	0.08	-0.0012
6	0.06	0.0017	0.09	0.0015

根据机器人各个关节角的变化范围以及实际工作的需要，取 $\theta_1 = -60^\circ, 0^\circ, 60^\circ$，$\theta_2 = 30^\circ, 40^\circ, 50^\circ$，$\theta_3 = 10^\circ, 20^\circ, 30^\circ, 40^\circ$，$\theta_4 = -60^\circ, -40^\circ, 20^\circ, 40^\circ, 60^\circ$，$\theta_5 = -60^\circ, -40^\circ, 20^\circ, 40^\circ, 60^\circ$，$\theta_6 = -90^\circ, -60^\circ, -30^\circ, 30^\circ, 60^\circ, 90^\circ$。一共产生 3×3×4×5×5×6=5400 组不同的关节角度组合，其中 5000 组作为 ELM 模型的训练样本集，另外 400 组作为检验的数据。

3.3　对关节坐标补偿的 PSO-ELM 机器人精度补偿法

对关节坐标补偿的 PSO-ELM 机器人精度补偿模型将机器人的理论关节角作为 PSO-ELM 模型的输入，关节角误差作为输出来训练 PSO-ELM 模型。PSO-ELM 训练过程的框图如图 4 所示。其中，$\theta^N = [\theta_1, \theta_2, \theta_3, \theta_4, \theta_5, \theta_6]^T$，$\theta^R = [\theta_1^R, \theta_2^R, \theta_3^R, \theta_4^R, \theta_5^R, \theta_6^R]^T$，ABB 机器人理论关节角 θ^N 经正运动学（理论 D-H 参数）计算得出理论末端位姿 T_E^N，理论末端位姿经逆运动学（实际 D-H 参数）求解得实际关节角 θ^R，于是可得关节角误差 $\Delta\theta = \theta^R - \theta^N$。故 PSO-ELM 模型的输入层节点为 6，输出层节点也为 6。

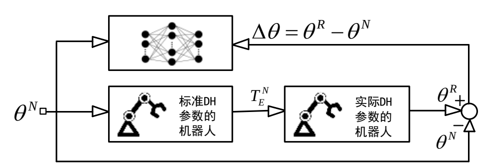


图 4　机器人关节坐标补偿的 PSO-ELM 训练模型

可以使用图 5 中描述的步骤来执行机器人末端执行器的定位过程。其中，θ^{mod} 是经过补偿后的修正的关节角，X^p 是预测位置，我们的目标是将机器人末端执行器移动到其工作空间中的理论位置 X^N。其中 ε 是机器人精度的上限。

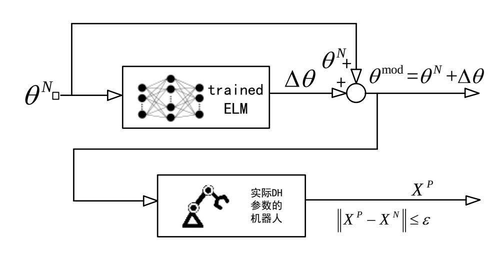


图 5　机器人关节坐标的补偿过程

为了体现该模型的准确性和优越性，采用 GA-ELM 模型与其做对比，GA-ELM 利用遗传算法为 ELM 寻找最优的 w 和 b，具体的算法流程参考文献[14]。经过多次实验，确定 PSO-ELM 的隐含层节点数为 68,种群规模为 40，迭代次数为 300，$C_1=C_2=2$，$V_{max}=1$，$V_{min}=-1$，$pop\max=2$，$pop\min=-2$，惯性权重的最大值 ω_{max} 为 0.9，最小值 ω_{min} 为 0.4，GA-ELM 的隐含层节点数为 58，种群规模为 100，迭代次数为 350，交叉概率为 0.6，变异概率为 0.01。ELM 的隐含层激励函数均选择“sig”函数。用 5000 组样本集训练模型，将 400 组检验数据代入训练好的模型，经过机器人逆运动学精度补偿后的位置误差如图 6 所示。

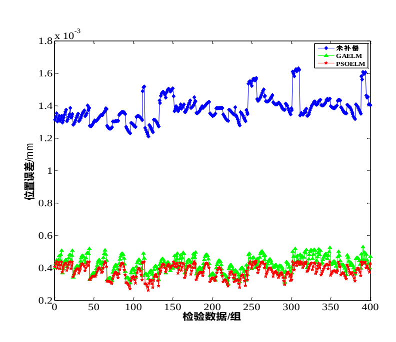


图 6　位置误差(400 组检验数据)

为了验证输入数据的一般性，根据机器人实际工作的需要，在机器人各个关节角的变化范围以内，取 $\theta_1=-45^\circ,30^\circ,45^\circ$，$\theta_2=40^\circ,45^\circ,50^\circ$，$\theta_3=20^\circ,30^\circ,40^\circ,50^\circ$，$\theta_4=-60^\circ,-30^\circ,30^\circ,45^\circ,60^\circ$，$\theta_5=-60^\circ,-30^\circ,30^\circ,45^\circ,60^\circ$，$\theta_6=-90^\circ,-60^\circ,-30^\circ,30^\circ,60^\circ,90^\circ$。产生与样本数据不同的 5400 组数据，从这 5400 组数据中随机生成 200 组数据，代入已训练完成的 PSO-ELM 进行仿真计算，位置误差如图 7 所示。

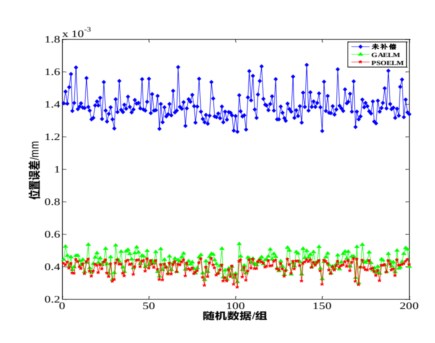


图 7　位置误差(200 组随机数据)

3.4　对直角坐标补偿的 PSO-ELM 机器人精度补偿法

对直角坐标补偿的 PSO-ELM 机器人精度补偿模型将机器人的理论关节角作为 PSO-ELM 模型的输入，实际位置与理论的位置误差作为输出来训练网络。PSO-ELM 训练过程的框图如图 8 所示。其中，$\theta^N=[\theta_1,\theta_2,\theta_3,\theta_4,\theta_5,\theta_6]^T$，ABB 机器人理论关节角 θ^N 经正运动学（理论 D-H 参数）计算得出理论的末端位置 $X^N=[x^N,y^N,z^N]^T$，θ^N 经正运动学（实际 D-H 参数）计算得出实际的位置 $X^R=[x^R,y^R,z^R]^T$，于是可得位置误差 $\Delta X=X^R-X^N$。故 PSO-ELM 模型的输入层节点为 6，输出层节点为 3。

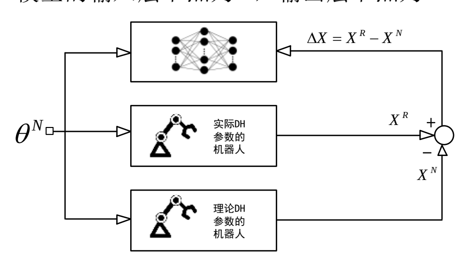


图 8　机器人直角坐标补偿的 PSO-ELM 训练模型

训练后的 PSO-ELM 模型将用于补偿机器人的位置误差。机器人末端执行器定位的详细步骤如图 9 所示，由于 ABB 机器人运动的位置只与前 3 个关节角 θ_1，θ_2，θ_3 有关，故位置的补偿只针对前 3 个关节角，J_θ 是机器人关节变量 $\theta_i(i=1,2,3)$ 的雅可比矩阵，θ^{mod} 是经过补偿后的关节角，实验的目标是将机器人末端执行器移动到其工作空间中的理论位置 X^N，其中 ε 是机器人精度的上限。

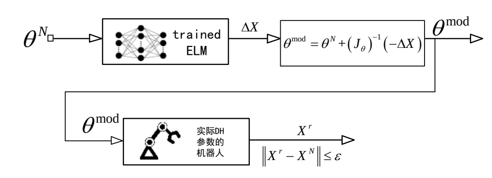


图 9　机器人直角坐标的补偿过程

为了体现该模型的准确性和优越性，采用 GA-ELM 模型与其做对比，经过多次实验，确定 PSO-ELM 的隐含层节点数为 65，种群规模为 50，迭代次数为 300，惯性权重的最大值 ω_{max} 为 0.9，最小值 ω_{min} 为 0.4，其他参数同上文。GA-ELM 的隐含层节点数为 73，种群规模为 80，迭代次数为 400，交叉概率为 0.6，变异概率为 0.01，ELM 的隐含层激励函数均选择 sig 函数。用 5000 组样本集训练模型，将 400 组检验数据代入训练好的模型，经过机器人逆运动学精度补偿后的位置误差如图 10 所示。

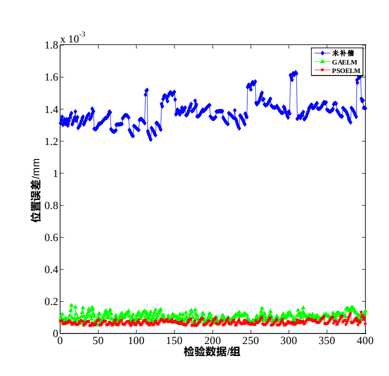


图 10　位置误差(400 组检验数据)

为了验证输入数据的一般性，将与上文相同的随机生成的 200 组数据，代入已训练完成的 PSO-ELM 进行仿真计算，位置误差如图 11 所示。

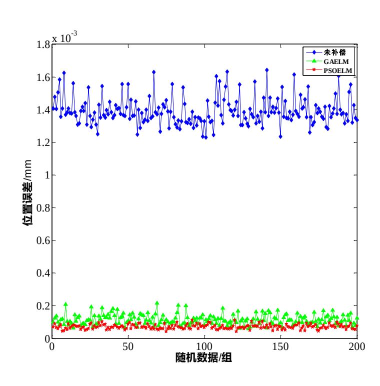


图 11　位置误差(200 组随机数据)

3.5　两种精度补偿方法的结果分析与比较

对上面的两种精度补偿方法的结果作对比分析，由图 6、7、10、11 分析可得表 3、4。

表 3　两种方法的位置精度比较（检验数据比较（400 组））

位置误差(mm)	最大值	最小值	平均值
未补偿	1.6294	1.2100	1.3806
关节坐标 GA-ELM	0.5292	0.3007	0.4214
关节坐标 PSO-ELM	0.4400	0.2599	0.3787
直角坐标 GA-ELM	0.1728	0.0525	0.1021
直角坐标 PSO-ELM	0.1319	0.0452	0.0682

表 4　两种方法的位置精度比较（随机数据比较（200 组））

位置误差(mm)	最大值	最小值	平均值
未补偿	1.6422	1.2301	1.3917
关节坐标 GA-ELM	0.5394	0.3007	0.4290
关节坐标 PSO-ELM	0.4498	0.2702	0.3955
直角坐标 GA-ELM	0.2151	0.0602	0.1156
直角坐标 PSO-ELM	0.1125	0.0418	0.0713

通过分析检验数据和随机数据可得，经过补偿后的机器人的位置误差明显低于未补偿之前，且对机器人直角坐标补偿后的位置误差低于对关节坐标补偿后的位置误差。在这两种方法中，PSO-ELM 的预测效果都优于 GA-ELM。对比检验数据与未补偿之前，经过关节坐标 GA-ELM 精度补偿法补偿后，平均位置误差降低了 69.48%，经过关节坐标 PSO-ELM 精度补偿法补偿后，平均位置误差降低了 72.57%，经过直角坐标 GA-ELM 精度补偿法补偿后，平均位置误差降低了 92.60%，经过直角坐标 PSO-ELM 精度补偿法补偿后，平均位置误差降低了 95.06%。对比随机数据与未补偿之前，经过关节坐标 GA-ELM 精度补偿法补偿后，平均位置误差降低了 69.17%，经过关节坐标 PSO-ELM 精度补偿法补偿后，平均位置误差降低了 71.58%，经过直角坐标 GA-ELM 精度补偿法补偿后，平均位置误差降低了 91.69%，经过直角坐标 PSO-ELM 精度补偿法补偿后，平均位置误差降低了 94.88%。

4　结束语

为了提高工业机器人在实际运用中的绝对定位精度，本文提出对机器人的关节坐标补偿和直角坐标补偿两种方法，采用粒子群优化算法优化的极限学习机模型（PSO-ELM）预测关节坐标的误差和直角坐标的误差，并与遗传算法优化的极限学习机(GA-ELM)模型进行对比。在这两个仿真实验中，PSO-ELM 的预测效果都优于 GA-ELM。而对机器人直角坐标补偿的方法要明显优于对关节坐标补偿的方法。对直角坐标进行补偿的 PSO-ELM 精度补偿法的预测精度最高，且具有良好的鲁棒性。

参考文献：

[1] Ma Le, Bazzoli P, Sammons P, *et al.* Modeling and calibration of high-order joint-dependent kinematic errors for industrial robots [J]. Robot Comput-Integr Manuf, 2017, 0: 1–15.

[2] 刘志，赵正大，谢颖，等. 考虑结构变形的机器人运动学标定及补偿 [J]. 机器人, 2015, 37 (3): 376-384. (Liu Zhi, Zhao Zhengda, Xie Ying, *et al.* Kinematic calibration and compensation for a robot with structural deformation [J]. Robot, 2015, 37 (3): 376-384.)

[3] Palmieri G, Palpacelli M, Carbonari L, et al, Vision-based kinematic calibration of a small-scale spherical parallel kinematic machine [J]. Robot Comput-Integr Manuf, 2018, 49: 162–169.

[4] 房立金，党鹏飞. 基于量子粒子群优化算法的机器人运动学标定方法 [J]. 机械工程学报，2016, 52 (7): 23-30. (Fang Lijin, Dang Pengfei. Kinematic calibration method of robots based on quantum-behaved particle swarm optimization [J]. Journal of Mechanical Engineering, 2016, 52 (7): 23-30.)

[5] 张旭，郑泽龙，齐勇. 6 自由度串联机器人 D-H 模型参数辨识及标定 [J]. 机器人，2016, 38 (3): 360-370. (Zhang Xu, Zheng Zelong, Qi Yong. Parameter Identification and calibration of D-H model for 6-DOF serial robots [J]. Robot, 2016, 38 (3): 360-370.)

[6] Švaco M, Šekoranja B, Šuligoj F. Calibration of an industrial robot using a stereo vision system [J] , Procedia Engineering. 2014, 69: 459-463.

[7] Park I W, Lee B J, Cho S H, et al, Laser-based kinematic calibration of robot manipulator using differential kinematics [J]. IEEE-ASME T MECH. 2012, 17 (6): 1059-1067.

[8] 王东署，迟健男. 机器人运动学标定综述 [J]. 计算机应用研究, 2007, 24 (9): 8-11. (Wang Dongshu, Chi Jiannan. Suvrey on robot kinematics calibration [J]. Application Research of Computers, 2007, 24 (9): 8-11.)

[9] Aoyagi S, Kohama A, Nakata Ya, et al, Improvement of robot accuracy by calibrating kinematic modelusing a laser tracking system, compensation of non-geometric errors using neural networks and selection of optimal measuring points using genetic algorithm [C]// Proc of IEEE International Conference on Intelligent Robots and Systems. 2010: 5660–5665.

[10] Wang Dali, Bai Yanhua, Zhao Jiying, Robot manipulator calibration using neural network and a camera-based measurement system [J]. Trans Inst Meas Control. 2010, 32 (4): 105-121.

[11] Zhong X L, Lewis J M, Rea H. Neuro-accuracy compensator for industrial robots [C]// Proc of IEEE International Conference on Neural Networks.

1994: 2797-2802.

[12] Nguyen H N, Zhou Jian. A calibration method for enhancing robot accuracy through integration of an extended Kalmanlter algorithm and an articial neural network [J]. Neurocomputing, 2015, 151: 996–1005.

[13] Huang Guangbin, Zhu Qinyu, Siew C K. Extreme learning machine: theory and applications [J]. Neurocomputing, 2006, 70 (1): 489-50.

[14] 梅益, 孙全龙, 喻丽华, 等. 基于 GA-ELM 的铝合金压铸件晶粒尺寸预测 [J]. 金属学报, 2017, 53 (9): 1125-1132. (Mei Yi, Sun Quanlong, Yu Lihua, *et al.* Grain size prediction of aluminum alloy dies castings based on GA-ELM [J]. Acta Metallurgica Sinia, 2017, 53 (9): 1125-1132.)

[15] Liu Dong, Liu Chunlei, Fu Qiang, *et al.* ELM evaluation model of regional groundwater quality based on the crow search algorithm [J]. Ecological Indicators, 2017, 81: 302-314.

[16] Kennedy J, Eberhart R. Particle swarm optimization [C]// Proc of IEEE International Conference on Neural Networks. 1995: 1942-1948.